

SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET SPLIT

DIPLOMSKI RAD

**UTJECAJ ULAGANJA U ISTRAŽIVANJE I
RAZVOJ NA RAST BDP-A U ZEMLJAMA
EUROPSKE UNIJE**

Mentor:

doc.dr.sc. Silvia Golem

Student:

Domagoj Jukić

Split, rujan, 2019.

SADRŽAJ:

1. UVOD.....	3
1.1. PROBLEM I PREDMET ISTRAŽIVANJA	3
1.2 . ISTRAŽIVAČKE HIPOTEZE	5
1.3. CILJEVI ISTRAŽIVANJA.....	5
1.4. METODE ISTRAŽIVANJA	6
1.5. DOPRINOS ISTRAŽIVANJA.....	6
1. 6. STRUKTURA I SADRŽAJ DIPLOMSKOG RADA	6
2.TEORIJSKI OKVIR.....	7
2.1. ISTRAŽIVANJE I RAZVOJ(R&D)	7
2.1.1.DEFINICIJA	7
2.1.2.MJERENJE	7
2.1.3. VAŽNOST ISTRAŽIVANJA I RAZVOJA	8
2.1.4. LJUDSKI RESURSI U ISTRAŽIVANJU I RAZVOJU	9
2.1.5. UTJECAJ DRŽAVE ILI ZAJEDNICE DRŽAVA NA SEKTOR ISTRAŽIVANJA I RAZVOJA	9
2.2. INOVACIJE KAO REZULTAT ISTRAŽIVANJA I RAZVOJA	12
2.3.ULAGANJE U ISTRAŽIVANJE I RAZVOJ U EU	13
2.3.1.ULAGANJE U ISTRAŽIVANJE I RAZVOJ PO SEKTORIMA	14
2.3.2. IZVORI FINANCIRANJA ISTRAŽIVANJA I RAZVOJA	14
2.3.3. UDIO OSOBA KOJE RADE U SEKTORU ISTRAŽIVANJA I RAZVOJA U UKUPNOJ RADNOJ SNAZI ZEMALJA ČLANICA EU	15
2.3.4.USPOREDBA ULAGANJA U ISTRAŽIVANJE I RAZVOJ IZMEĐU EU I OSTATKA SVIJETA	16
2.4. MODELI KOJI OBJAŠNJAVAJU UTJECAJ ISTRAŽIVANJA I RAZVOJA NA RAST BDP-A	17

2.4.1. SOLOWLJEV MODEL RASTA	17
2.4.2. ULAGANJA U ISTRAŽIVANJE I RAZVOJ I ENDOGENI RAST	18
2.4.3. SUVREMENI TEORIJSKI MODELI KOJI POVEZUJU ULAGANJE U ISTRAŽIVANJE I RAZVOJ SA GOSPODARSKIM RASTOM	19
3. EMPIRIJSKI DIO RADA	20
3.1. PRETHODNA EMPIRIJSKA ISTRAŽIVANJA	20
3.2. STATISTIČKA ANALIZA UTJECAJA ULAGANJA ISTRAŽIVANJA I RAZVOJA NA STOPU RASTA BDP-A.....	21
3.2.1. UVOD	21
3.2.2. ODABIR KONTROLNIH VARIJABLI U MODELU I NJIHOV OČEKIVANI UTJECAJ NA RAST BDP-A.....	22
3.2.3. SPECIFIKACIJA MODELA	23
3.2.4. GRAFIČKA ANALIZA VARIJABLI	24
3.2.5. REZULTATI STATISTIČKE ANALIZE	29
3.2.5.1. DESKRIPTIVNA STATISTIKA.....	29
3.2.5.2. PROCJENA VARIJABLI DINAMIČKOG PROCJENITELJA	30
3.2.5.3. TESTIRANJE MULTIKOLINEARNOSTI.....	30
3.2.5.4. DINAMIČKI PANEL PROCJENITELJ I PROCIJENJENI MODEL	31
3.2.5.5. TESTIRANJE PROBLEMA ENDOGENOSTI I AUTOKORELACIJE	33
3.3. RASPRAVA REZULTATA	34
4. ZAKLJUČAK.....	35
LITERATURA	37
SAŽETAK.....	42
SUMMARY	43

1. UVOD

1.1. PROBLEM I PREDMET ISTRAŽIVANJA

Istraživanje i razvoj dobivaju sve važniju ulogu u suvremenoj ekonomiji. U svom radu Bečić i Dabić (2007) objašnjavaju razliku između istraživanja i razvoja. Istraživanje se povezuje sa stvaranjem novog znanja, dok se razvoj povezuje s primijenjenim znanjem. Iako su različiti, oba pojma tvore cjelinu. Postoje 3 vrste istraživanja i razvoja (OECD, 2002 navedeno u Hodžić, 2012):

- **temeljno istraživanje** – teorijski ili pokusni rad napravljen ponajprije radi postignuća novih znanja o osnovama pojava i činjenica bez konkretne praktične primjene
- **primijenjeno istraživanje** – teorijski ili pokusni rad napravljen radi postignuća novih znanja i usmjeren je prije svega na ostvarivanje praktičnog cilja
- **razvojno istraživanje** – rad temeljen na rezultatima znanstvenog istraživanja i praktičnog iskustva, usmjeren stvaranju novih materijala, proizvoda i sustava te uvođenju novih procesa, ili poboljšanju postojećih.

Aghion et al. (2005 u Tomljanović, 2017a) smatraju da su ulaganja u istraživanje i razvoj jako bitan faktor koji donosi socio-ekonomske promjene, a zemlje ulažu u znanost i razvoj tehnologije radi ostvarenja konkurentske prednosti. Ako su ta ulaganja produktivna, socio-ekonomske promjene bi trebale biti pozitivne, a ukoliko nisu, onda bi trebale biti negativne.

Analizirajući sektore koji ulažu u istraživanje i razvoj, Guelllec i Pottelsberghe (2001) naglašavaju da je poslovni sektor jako bitan, a to se najviše uočava kroz efekte prelijevanja te kroz sposobnost poslovnog sektora za apsorpciju tehnologija i pozitivan učinak na društvo. Autori smatraju kako bi zbog poticanja poslovnog sektora na ulaganje i cjelokupnog gospodarskog rasta, države trebale liberalizirati trgovinu i omogućiti pristup tehnologijama iz inozemstva (Damien et al., 2003 u Tomljanović, 2017b).

Utjecaj istraživanja i razvoja na ekonomski rast tema je brojnih znanstvenih radova, kako teorijskih, tako i empirijskih. Jedan od najvažnijih je model endogenog rasta, odnosno teorijski model koji povezuje ulaganja u istraživanje i razvoj i ravnotežnu stopu rasta BDP-a po radniku. Malešević i Ćorić (2013) ističu da je najvjerojatnije ključni dio tehnološkog napretka posljedica ulaganja u istraživanje i razvoj. Dolazi se do zaključka da je ravnotežna

stopa rasta BDP-a po radniku usko povezana sa ulaganjem u istraživanje i razvoj. Ravnotežna stopa rasta BDP-a po radniku ne ovisi samo o ulaganju u istraživanje i razvoj, nego i o produktivnosti procesa istraživanja. Ekonomske politike ne mogu puno utjecati na produktivnost procesa istraživanja jer nema „obrasca“ po kojem se stvaraju kvalitetne ideje.

Zagler (1998), kako je navedeno u radu Skoke i Kandžije (2013), objašnjava kako slabo razvijene zemlje nemaju razvijen R&D- research and development - sektor, odnosno sektor istraživanja i razvoja. Njihov R&D sektor nije razvijen jer nemaju dovoljno inovacija u odnosu na razvijene zemlje. Ben-David i Loewy (1998), kako je navedeno u radu Skoke i Kandžije (2013), smatraju da konvergencija među zemljama ovisi o trgovinskoj liberalizaciji jer bi se tako inovacije mogle širiti na manje razvijene zemlje koje bi se tako mogle više razviti i približavati razvijenim zemljama. Danas je trgovina prilično liberalizirana pa se tako i očekuje brži razvoj manje razvijenih zemalja. „Ujedno, čini se da bi uloga istraživanja i razvoja u velikim i malim zemljama mogla biti različita. Dok u velikim zemljama veći rashodi za tu djelatnost mogu povećati stopu inovacija, u malim zemljama ponajprije služe za olakšavanje transfera tehnologije iz inozemstva“ (Bassanini et al., 2000 u Bejaković, 2003).

Tomljanović (2017a) smatra da je pri analizi povezanosti ulaganja u istraživanje i razvoj i rasta BDP-a potrebno obratiti pozornost na obrazovanje. Važnost obrazovanja je velika jer se obrazovanjem stječu znanja i vještine koje se mogu koristiti u istraživanju i razvoju i utjecati na njihovu produktivnost, a produktivno istraživanje i razvoj pozitivno utječu na rast BDP-a.

„Prema Lucasu (1988), ljudski kapital, odnosno preciznije njegova akumulacija, predstavlja osnovnu determinantu ravnotežne stope rasta BDP-a po radniku. Ljudski kapital predstavlja količinu znanja i vještina koju određeni radnik posjeduje i koristi u radu. Potencijalni utjecaj ljudskog kapitala na razinu i ravnotežnu stopu rasta BDP-a po radniku zasniva se na stajalištu kako je produktivnost rada direktno proporcionalna razini znanja i vještina radne snage. Brža akumulacija ljudskog kapitala vodi bržem rastu produktivnosti te zbog toga i većoj ravnotežnoj stopi BDP-a po radniku. Akumulacija znanja i vještina rezultat je prije svega procesa „formalnog“ obrazovanja“ (Malešević i Ćorić, 2013).

Pozitivan utjecaj istraživanja i razvoja na BDP prepoznali su i nositelji politika EU. U svom radu Hodžić (2012) ističe da istraživanje i razvoj dobivaju sve veću važnost u Europskoj Uniji jer se želi ostvariti konkurentna prednost u odnosu na SAD, Japan i ostale visoko razvijene

zemlje. Mnoge članice EU koriste fiskalne olakšice poput poreznih olakšica kako bi potakle ulaganja u istraživanje i razvoj. Inovacije su jako bitan faktor u modernoj ekonomiji jer se njima može ostvariti značajna konkurentna prednost. Država ima veliku ulogu u poticanju inovacija jer može koristiti fiskalne olakšice kao poticaj za stvaranje inovacija te ulaganjem u obrazovanje može omogućiti znanja i vještine koji su potrebni za stvaranje inovacija.

„Zemlje EU-a potiče se da ulažu 3 % BDP-a u istraživanja i inovacije do 2020. (1 % javnog financiranja, 2 % ulaganja iz privatnog sektora) – očekuje se da će se time otvoriti 3,7 milijuna radnih mjesta i povisiti godišnji BDP EU-a za gotovo 800 milijardi EUR. S pomoću javnog sektora podupire se privatni sektor i uklanjaju problemi dolaska ideja na tržište – uključujući manjak sredstava, fragmentirane istraživačke sustave i tržišta, nedovoljno korištenje javne nabave za inovacije i sporo postavljanje standarda. EU želi stvoriti i jedinstveno europsko istraživačko područje u okviru kojeg će istraživači moći raditi bilo gdje u Europi, a prekogranična suradnja će se podržati i podupirati“ (Europska unija, 2016).

1.2. ISTRAŽIVAČKE HIPOTEZE

Glavni cilj ovog diplomskog rada je testirati sljedeću hipotezu:

H0-nema značajnog utjecaja ulaganja u istraživanje i razvoj na rast BDP-a

H1-postoji značajan utjecaj ulaganja u istraživanje i razvoj na rast BDP-a

Postavljene istraživačke hipoteze će se testirati koristeći adekvatne ekonometrijske tehnike procjene utjecaja ulaganja u istraživanje i razvoj na rast BDP-a u primjerenom statističkom programu, te će se na temelju dobivenih statističkih rezultata zaključiti o snazi i značajnosti utjecaja.

1.3. CILJEVI ISTRAŽIVANJA

Glavni cilj ovog istraživanja je:

- analizirati vezu između ulaganja u istraživanje i razvoj i rasta BDP-a na temelju pregleda teorijske i empirijske literature, istraživanja literature i regresijske analize

Pomoćni ciljevi ovog istraživanja su :

- analizirati koliko se ulaže u istraživanje i razvoj u državama EU
- istražiti koji su izvori sredstava za istraživanje i razvoj u EU

- analizirati udio osoba koje rade u sektoru istraživanja i razvoja u ukupnoj radnoj snazi zemalja članica EU

1.4. METODE ISTRAŽIVANJA

U ovom istraživanju koristit će se statističke metode procjene utjecaja. Uspoređivat će se zemlje EU prema pokazateljima vezanim za istraživanje i razvoj i prema stopama rasta BDP-u, a na temelju panel analize tih podataka dolazi se do zaključka o povezanosti ulaganja u istraživanje i razvoj i rasta BDP-a. Koristit će se i panel ekonometrijske tehnike kako bi se analizirala povezanost ulaganja u istraživanje i razvoj i BDP-a. Podaci koji su potrebni za ovo istraživanje i za korištenje ovih metoda mogu se prikupljeni su preko različitih baza podataka: Eurostat, World bank, OECD, DZS i sl.

1.5. DOPRINOS ISTRAŽIVANJA

Iako postoje mnogi radovi na ovu temu koji su dali svoj doprinos razumijevanju ove tematike u ekonomiji, ovo istraživanje bi trebalo dati doprinos razumijevanju ove tematike putem kritičkog pregleda recentne literature, te empirijskog istraživanja..

1. 6. STRUKTURA I SADRŽAJ DIPLOMSKOG RADA

U uvodnom dijelu diplomskog rada navest će se problem i predmet istraživanja, ciljevi, metode i doprinos istraživanja, istraživačke hipoteze te struktura diplomskog rada. Korištenjem i analiziranjem literature vezane uz ovu temu, teorijski će se obraditi predmet istraživanja. U empirijskom dijelu diplomskog rada pregledat će se prijašnja empirijska istraživanja, te će se statistički analizirati utjecaj ulaganja u istraživanje i razvoj na stopu rasta BDP. Nakon teorijske obrade predmeta istraživanja, analize prijašnjih istraživanja i vlastitog empirijskog istraživanja, slijedi zaključak o utjecaju ulaganja u istraživanje i razvoj na BDP.

2. TEORIJSKI OKVIR

2.1. ISTRAŽIVANJE I RAZVOJ (R&D)

2.1.1. DEFINICIJA

„Istraživanje i razvoj predstavlja kolektivni organizirani napor povećanja znanja zasnovanog na znanosti ili inovacijama proizvoda i procesa. Istraživanje i razvoj nerijetko zahtjeva znatna financijska sredstva, no ono je često, posebno u tehnološki dinamičnim industrijama, osnova razvoja novih procesa putem kojih se smanjuju troškovi opskrbe i uvode novi proizvodi, čime se osigurava konkurentska prednost. Istraživanje i razvoj mogu predstavljati i funkciju u organizaciji, odnosno organizacijsku jedinicu čija je osnovna zadaća razvoj novih proizvoda ili usluga, poboljšanje postojećih proizvoda ili usluga, pronalaženje nove uporabne vrijednosti starih proizvoda ili usluga, te unapređenje i razvijanje postojećih proizvodnih odnosno tehnoloških poslovnih procesa.“ (Društveno odgovorno poslovanje u Hrvatskoj, 2012.).

DZS (2005) navodi da je istraživanje i razvoj sustavan stvaralački rad s ciljem povećanja znanja o prirodi, čovjeku, kulturi i društvu te primjene nastalih otkrića.

Galović (2016) smatra da istraživanje i razvoj podrazumijeva upotrebu resursa i ostvarenje ideja s ciljem razvoja proizvoda i procesa.

Na temelju definicija ovih autora, istraživanje i razvoj može se definirati kao kolektivni napor s ciljem povećanja znanja i razvoja proizvoda i procesa.

2.1.2. MJERENJE

U okviru empirijskih istraživanja, istraživanje i razvoj se, kao varijabla, mjeri na različite načine. U svom radu Tomljanović (2017a) mjeri istraživanje i razvoj putem 8 pokazatelja:

- ulaganja u istraživanje i razvoj (% BDP-a)
- ulaganja u istraživanje i razvoj per capita (u eurima)
- struktura ulaganja u istraživanje i razvoj, tj. ulaganja poslovnoga, javnoga i sektora visokoga obrazovanja (% BDP-a)
- obrazovna struktura aktivnoga stanovništva (udio (%) stanovništva od 25 do 64 godine sa završenim sekundarnim i tercijarnim obrazovanjem)
- udio proizvoda visoke tehnologije u ukupnome izvozu prerađivačke industrije (%)

- udio stanovnika koji sudjeluju u programima cjeloživotnoga obrazovanja (% stanovništva od 25 do 64 godine)
- novih doktori znanosti na 1.000 stanovnika
- broj istraživača na milijun stanovnika

U svom izvješću DZS (2018) mjeri istraživanje i razvoj u RH u 2017. putem ovih pokazatelja: bruto domaći izdaci za istraživanje i razvoj, ukupan broj zaposlenih u sektoru istraživanja i razvoja, ukupan broj istraživača i sektori koji se bave istraživanjem i razvojem.

Kojić et.al (2011) navode pokazatelje koji mjere istraživanje i razvoj:

- bruto domaća ulaganja u istraživanje i razvoj
- ulaganja privatnog sektora u istraživanje i razvoj
- ulaganja države u istraživanje i razvoj
- ulaganje visokog obrazovanja u istraživanje i razvoj
- odljevi državnih budžetskih sredstava na istraživanje i razvoj
- ukupan broj zaposlenih u sektoru istraživanja i razvoja
- ukupan broj zaposlenih koji rade puno radno vrijeme na poslovima istraživanja i razvoja na nacionalnom teritoriju za razdoblje od godinu dana
- broj prijavljenih patenata
- broj priznatih patenata
- domaće PCT prijave (međunarodne prijava patenta)

2.1.3. VAŽNOST ISTRAŽIVANJA I RAZVOJA

U svom radu Hodžić (2014) objašnjava važnost i utjecaj istraživanja i razvoja te smatra da je ta djelatnost jako bitna jer se preko nje ostvaruju nova znanja koja dovode do novih proizvoda i usluga, otvaraju se nova tržišta i uvode se novi procesi u poduzeća. Istraživanje i razvoj utječe na cjelokupno gospodarstvo i društvo jer može povećati gospodarski rast i zaposlenost, a na kraju i životni standard društva.

EU (2016) navodi da istraživanje doprinosi stvaranju novog znanja i razvoju novih proizvoda, procesa i sl. kojima se omogućuje veća produktivnost, industrijska konkurentnost i u konačnici blagostanje.

2.1.4. LJUDSKI RESURSI U ISTRAŽIVANJU I RAZVOJU

U svom radu Galović (2016) smatra da su ljudski resursi bitan segment istraživanja i razvoja u javnom i privatnom sektoru i navodi da je dosta istraživanja potvrdilo značaj osoblja za istraživanje i razvoj, a najveći značaj imaju istraživači.

Galović (2016) objašnjava dionike osoblja za istraživanje i razvoj:

1. **Istraživači** - su profesionalno osoblje uključeno u stvaranje novih ideja, proizvoda, procesa i sl.
2. **Tehničko i stručno osoblje** - dionici istraživanja i razvoja koji izводе znanstvene i tehničke zadatke koji uključuju primjenu koncepata i operativnih metoda, a najčešće ih nadziru istraživači
3. **Ostalo pomoćno osoblje** - obrtnici, menadžeri koji se uglavnom bave financijskim i kadrovskim poslovima, tajničko i administrativno osoblje...

2.1.5. UTJECAJ DRŽAVE ILI ZAJEDNICE DRŽAVA NA SEKTOR ISTRAŽIVANJA I RAZVOJA

Država ili zajednica država mogu imati velik utjecaj na istraživanje i razvoj putem različitih mjera i politika kojima mogu povećati ulaganja u ovaj sektor. Bejaković (2003) navodi da je zaključak brojnih provedenih empirijskih istraživanja kako je društvena korist povrata od ulaganja u istraživanje i razvoj veća od privatnih povrata od tih ulaganja, a to ukazuje na važnost istraživanja i razvoja za ukupan gospodarski rast i opravdava državne poticaje za ta ulaganja. Tvrtke (privatni sektor) donose odluke o ulaganjima u istraživanje i razvoj na temelju ostvarenih ili očekivanih privatnih povrata od ulaganja i istraživanje i razvoj, a više autora smatra da je taj povrat dosta niži od ukupnog društvenog povrata, a to ukazuje na važnost države, odnosno državnih poticaja za ulaganja u istraživanje i razvoj. Hodžić (2012) navodi 3 sredstva poticanja ulaganja u istraživanje i razvoj:

- suradnja istraživačkog centra i privatnog sektora
- porezni poticaji
- direktno financiranje iz proračuna

MZOŠ (2008) navodi da suradnja između privatnog sektora i znanstvene zajednice pridonosi razvoju inovacija, a to znači da se tom suradnjom potiču ulaganja u istraživanje i razvoj. Najbolji primjer ovakve suradnje je model Triple Helix (Etzkowitz, 2002 navedeno u OECD,

2013) kao model koji se sastoji od 3 dionika (sveučilišta, vlade i industrije) koji su međusobno povezani i koji imaju zajednički cilj, kapitalizaciju znanja. U svom radu Kraljić (2016) smatra da se inkubatori, tehnološki parkovi ili centri izvrsnosti pojavljuju kao rezultat međusobne povezanosti između tri dionika ovog modela: sveučilišta, vlade i industrije (slika 1.), a sva tri dionika ovog modela moraju biti proaktivni, otvoreni za stjecanje novih znanja i spremni za razmjenu znanja. Također, niti jedan dionik ne bi trebao biti „vođa“ novih institucionalnih oblika kao što su inkubatori i ne bi trebao preuzimati uloge drugog dionika u svrhu rješavanja određenog problema.



Slika 1: Triple Helix

Izvor: InfoTrend (2014)

U svom radu Hodžić (2012) smatra da porezni poticaji za istraživanje i razvoj potiču ulaganja u istraživanje i razvoj i utječu na smjer razvoja poduzeća. OECD (2003), kako je navedeno u radu Hodžić (2014), navodi tri najčešća oblika poreznih poticaja za istraživanje i razvoj:

- **porezne odgode** - odgoda plaćanja poreza

- **porezni odbitak** - smanjenje osnovice poreza na dobit za iznos koji premašuje stvarna ulaganja u istraživanje i razvoj
- **porezni kredit** - smanjenje porezne obveze za dio izdataka za istraživanje i razvoj

Također, Hodžić (2012) objašnjava kada se upotrebljavaju porezni poticaji za istraživanje i razvoj, a kada direktno financiranje istraživanja i razvoja iz proračuna (subvencije, zajmovi, dotacije). To prvenstveno ovisi o politici države; porezni poticaji se koriste ako se žele potaknuti ulaganja privatnog sektora u istraživanje i razvoj, odnosno ako se želi potaknuti što više poduzeća, a direktno financiranje iz proračuna se koristi više kao potpora istraživanju i razvoju. Pottelsberghe i sur. (2003), kako je navedeno u radu Šimurine i Galić (2017), navode razlike između poreznih poticaja i direktnog financiranja iz proračuna. Najvažnija razlika je u tome što su porezni poticaji neutralnije sredstvo jer putem ovih poticaja država ne odabire poduzeća koja će dobiti poticaje niti odlučuje na koji način će ta poduzeća ulagati u istraživanje i razvoj, odnosno u koje će područje istraživanja i razvoja uložiti ta sredstva. Direktno financiranje iz proračuna se više odnosi na specifična poduzeća i na specifična područja istraživanja i razvoja u koja će ta poduzeća ulagati. Niži administrativni troškovi poreznih poticaja u odnosu na direktno financiranje iz proračuna su druga bitna razlika. Treća bitna razlika odnosi se na dostupnost informacija o načinu provođenja poreznih poticaja koji su dostupniji u odnosu na informacije o načinu provođenja direktnog financiranja iz proračuna. Četvrta bitna razlika odnosi se na kontrolu proračuna. Puno je lakše kontrolirati proračun kada se koristi direktno financiranje iz proračuna jer se kod tog sredstva poticanja izdvaja točno određeni iznos, a kod poreznih poticaja se ne zna koliko će poduzeća koristiti te poticaje pa se tako ne zna ni iznos koji će se „izgubiti“ kroz porezne poticaje.

Država može utjecati na istraživanje i razvoj i preko obrazovanja, odnosno politika i mjera vezanih za obrazovanje. Bejaković (2003) zaključuje da se ulaganjem u obrazovanje država sigurno razvija jer obrazovani radnici putem znanja i vještina koje posjeduju više pridonose istraživanju i razvoju nego neobrazovani radnici. Lažnjak i Švarc (2001) smatraju da je znanje pokretač inovacija i da je razina inovativnosti jedne države veća ako je veća uporaba visokoobrazovane radne snage.

Država može utjecati na istraživanje i razvoj putem politika i mjera kojima se određuje otvorenost tržišta. Bilas i Franc (2018) smatraju da slobodna trgovina i slobodno kretanje kapitala pozitivno djeluju na inovacije u zemljama u razvoju. Otvorenost može motivirati

domaće proizvođače te bi oni mogli postati inovativniji i produktivniji, a uz to otvorenost omogućava pristup inozemnom znanju i tehnologijama.

Prester (2010), kako je navedeno u radu Hodžić (2014), smatra da država mora osigurati stabilno ekonomsko okruženje, nisku inflaciju i niske kamatne stope kako bi potaknula inovacije koje su jako bitan segment istraživanja i razvoja.

2.2. INOVACIJE KAO REZULTAT ISTRAŽIVANJA I RAZVOJA

Galović (2016) navodi da je istraživanje i razvoj čimbenik razvoja inovacija i da su inovacije rezultat istraživanja i razvoja. U svom radu Bilas i Franc (2018) definiraju inovacije i oblike inovacija. Inovacije se mogu definirati kao stvaranje novih znanja i tehnologija te usvajanje znanja i tehnologija koje su razvijene negdje drugdje. Inovacije dovode do stvaranja novih proizvoda, usluga i tržišta. Galović (2016) navodi kako su inovacije rezultat istraživanja i razvoja. OECD (2007), kako je navedeno u radu Bilas i Franc (2018), navodi 4 oblika inovacija:

- **inovacije proizvoda** -uvođenje novih proizvoda ili usluga
- **inovacije procesa** -uvođenje novih načina proizvodnje i distribucije
- **marketinške inovacije** -novi dizajn i pakiranje, nove metode određivanja cijena...
- **organizacijske inovacije** - stvaranje novih praksi poslovanja, stvaranje nove organizacije radnih mjesta...

Pavlišić (2016) smatra da je inovacije teško mjeriti. Na mikroekonomskoj razini (na razini poduzeća) inovacije se mogu mjeriti preko prihoda od novih proizvoda, veličine izdataka za istraživanje i razvoj, broja patenata i sl. Na makroekonomskoj razini (na razini države) inovacije se mogu mjeriti kroz razinu ulaganja u istraživanje i razvoj (kao postotak BDP-a ili kao ukupan iznos), a u novije vrijeme postoje indeksi kojima se mjeri razina inovativnosti države i njezin inovacijski potencijal.

Cameron (1998), kako je navedeno u radu Pavlišić (2016), zaključuje da postoji značajna pozitivna veza između inovacija i mjere kojom se izražava output te navodi 3 zaključka njegove analize:


1. Inovacije značajno doprinose ekonomskom rastu
2. Postoji značajno prelijevanje efekta inovacija između zemalja, poduzeća i industrija

3. Postoji tendencija lokaliziranja prelijevanja inovacija putem udruživanja industrija u klastere

Jovičić i Petković (2016) zaključuju da su najkonkurentnija svjetska gospodarstva ujedno i najinovativnija. Kao primjere navodi Japan, SAD, Finsku, Južnu Koreju, Dansku, Veliku Britaniju, Singapur, Tajvan, Kanadu, Švedsku, Nizozemsku, Njemačku, Švicarsku i Hong Kong i smatra da je zajednička točka ovih ekonomija podjednako ulaganje u razvoj inovacija, državni sektor i privatni sektor.

2.3.ULAGANJE U ISTRAŽIVANJE I RAZVOJ U ZEMLJAMA EU

Eurostat (2018) navodi da je prosječan udio ulaganja u istraživanje i razvoj u BDP-u za EU-28 u 2006.g. iznosio 1,76% te je do 2012. narastao na 2,01% BDP-a. Od 2012. do 2016.g., prosječan udio je malo narastao; sa 2,01% u 2012.g. na 2,04% u 2016.g. Graf 1. prikazuje ulaganja odabranih zemalja u istraživanje i razvoj. Odabrano je pet zemalja kao primjer; dvije koje najviše ulažu u istraživanje i razvoj, dvije koje najmanje ulažu i Hrvatska kako bi se vidjelo koliko naša država ulaže u odnosu na ostale članice EU. Prema podacima Eurostata (2018) od svih država članica EU u 2016.godini, Švedska je najviše ulagala u istraživanje i razvoj (3,25% BDP-a), a nakon nje Austrija (3,09% BDP-a). 9 država članica je ulagalo manje od 1% BDP-a u istraživanje i razvoj, a svaka od tih 9 članica je pristupila EU 2004.g. ili kasnije. Hrvatska spada u tih 9 država, a najmanje su ulagali Rumunjska (0,48% BDP-a) i Latvija (0,44% BDP-a).




Graf 1: Ulaganja odabranih zemalja članica EU u istraživanje i razvoj (kao postotak BDP-a) u 2016.g.

Izvor :Izrada autora na temelju podataka sa Eurostata,

2.3.1.ULAGANJE U ISTRAŽIVANJE I RAZVOJ PO SEKTORIMA

Prema podacima Eurostata (2018), promatrajući ulaganja u istraživanje i razvoj (kao postotke BDP-a) po sektorima u 2016.g.(graf 2.) , najviše se ulagalo u privatni sektor. Ulaganja u privatni sektor iznosila su 1,32% BDP-a u 2016.g. Drugi sektor po ulaganjima u istraživanje i razvoj je sektor visokog obrazovanja, a ulaganja u taj sektor iznose 0,47% BDP-a u 2016.g. Treći sektor po ulaganjima je državni sektor (0,23%BDP-a u 2016.g.),a četvrti je privatni neprofitni sektor (0,02% BDP-a u 2016.g.).




Graf 2: Ulaganja u istraživanje i razvoj(kao postotci BDP-a) po sektorima u 2016.g.(EU-28)

Izvor:Izrada autora na temelju Eurostata

2.3.2. IZVORI FINANCIRANJA ISTRAŽIVANJA I RAZVOJA

Prema podacima Eurostata (2018) u 2015.g. u EU (EU-28) većina financiranja za istraživanje i razvoj potječe iz privatnog sektora (55,3% financiranja za istraživanje i razvoj). Iz državnog sektora potječe 31,3% financiranja, a 10,8% financiranja potječe izvan EU-28 (inozemna financiranja). Financiranja iz sektora visokog obrazovanja iznose 0,9%, a iz privatnog neprofitnog sektora 1,7%.




Graf 3: Izvori financiranja za istraživanje i razvoj u 2015.g.(EU-28)

Izvor: Izrada autora na temelju Eurostata,

2.3.3. UDIO OSOBA KOJE RADE U SEKTORU ISTRAŽIVANJA I RAZVOJA U UKUPNOJ RADNOJ SNAZI ZEMALJA ČLANICA EU

Za ovaj graf (graf 4.) odabrane su dvije zemlje članice EU koje imaju najveći udio osoba koje rade u sektoru istraživanja i razvoja u ukupnoj radni snazi, dvije koje imaju najmanju udio i prosjek EU-28 koji je odabran radi bolje usporedbe između zemalja članica EU. Prema Eurostatu (2018), udio osoba koje rade u sektoru istraživanja i razvoja u ukupnoj radnoj snazi

u EU-28 u 2015.godini iznosi 1,2%. Taj je udio u Danskoj u 2015.godini veći od 2%, u Luksemburgu iznosi 1,9%, u Cipru iznosi 0,3% te u Rumunjskoj 0,4%.




Graf 4: Udio osoba koje rade u sektoru istraživanja i razvoja u ukupnoj radnoj snazi u odabranim zemljama članicama EU-28 u 2015.g.

Izvor: Izrada autora na temelju Eurostata,

2.3.4. USPOREDBA ULAGANJA U ISTRAŽIVANJE I RAZVOJ IZMEĐU EU I OSTATKA SVIJETA

Prema podacima o ulaganju u istraživanje i razvoj preuzetih sa Eurostata (2018), u cijelom promatranom razdoblju (2006.-2016.) najviše je ulagao Japan, a najmanje Kina sve do 2015.g. kada je prestigla EU po izdacima za istraživanje i razvoj koji se promatraju kao udio u BDP-u.

Na temelju ovog grafa (graf 5.) mogu se iznositi različita mišljenja o utjecaju ulaganja u istraživanje i razvoj na razvoj neke države, odnosno na rast BDP-a te promatrane države. Kroz obradu literature i kroz empirijski dio ovog diplomskog rada, doći će se do općeg zaključka o ovom problemu.



(*) 2008 and 2013: break in series. 2016: not available.
 (*) Excludes most or all capital expenditure. 2015: provisional. 2016: not available.
 (*) 2009: break in series. 2016: not available.
 (*) 2016: provisional.
 Source: Eurostat (online data code: rd_e_gertot)

Graf 5: Usporedba ulaganja u istraživanje i razvoj (kao postotci BDP-a) između EU i ostatka svijeta u razdoblju od 2006.-2016.g.

Izvor: Eurostat,

2.4. MODELI KOJI OBJAŠNJAVAJU UTJECAJ ISTRAŽIVANJA I RAZVOJA NA RAST BDP-A

2.4.1. SOLOWLJEV MODEL RASTA

Skoko i Kandžija (2013) navode da je neoklasični Solowljev model prvi model koji povezuje tehnologiju i ekonomski rast. Ekonomski rast se može promatrati kroz rast BDP-a, a tehnologija kroz istraživanje i razvoj. U svom radu Mervar (1999) objašnjava Solowljev model rasta. Solowljev model ima nekoliko pretpostavki; u ekonomiji postoji samo jedno dobro kojeg je moguće potrošiti ili ga koristiti kao investiciju; broj stanovnika i stopa štednje su egzogeno utvrđeni; postoji samo realni sektor gospodarstva; vlada savršena konkurencija; uvijek je puna zaposlenost gospodarstva; proizvodna funkcija je linearno homogena s radom i kapitalom kao proizvodnim faktorima, konstantnim prinosima obujma, te pozitivnim, ali

opadajućim prinosima faktora proizvodnje, te endogeno određenom supstitutivnošću tih istih faktora; Tehnički napredak je egzogen, a tehnologija je javno dobro koje je besplatno i svima na raspolaganju. Dugoročna ravnoteža u Solowljevog modelu postiže se kada odnos kapitala i rada dosegne razinu u kojoj je štednja po stanovniku jednaka vrijednosti potrebnoj da se opreme novi pripadnici radne snage i da se zamijeni otpisani kapital. Ako gospodarstvo nije na toj razini, postepeno će se približavati stanju dugoročne ravnoteže jer ako raste (pada) kapital po stanovniku, granična proizvodnost kapitala pada (raste) zbog opadajućih prinosa faktora proizvodnje, pa se omjer rada i kapitala približava vrijednosti koja je karakteristična za stanje dugoročne ravnoteže. Ako je tehnološki napredak besplatan i dostupan svima, Solowljev model predviđa konvergenciju stope rasta dohotka po stanovniku bez obzira na početna stanja gospodarstava. Solowljev model je jedan od najznačajnijih doprinosa teoriji ekonomskog rasta i dan danas se smatra relevantnim, bez obzira na određene nedostatke.

2.4.2. ULAGANJA U ISTRAŽIVANJE I RAZVOJ I ENDOGENI RAST

Malešević i Ćorić (2013) navode da se pojavilo puno modela kao odgovor na nedostatke neoklasičnog (Solowljeva) modela rasta. Ovi modeli se nazivaju **modelima engodenog rasta** te se oni fokusiraju na objašnjavanje tehnološkog napretka i dugoročnog ekonomskog rasta. U svom radu Mervar (1999) navodi da modeli endogenog rasta ekonomski rast vide kao endogeni rezultat ekonomskog sistema za razliku od neoklasičnog modela u kojem je ekonomski rast određen egzogeno determiniranom stopom tehnološkog napretka.

Malešević i Ćorić (2013) navode da modeli koji pokušavaju objasniti tehnološki napredak kroz ulaganja u istraživanje i razvoj čine jednu skupinu modela ili teorija endogenog rasta. Postoje dvije grane ove skupine modela ili teorija endogenog rasta. Radovi u prvoj grani tehnološki napredak objašnjavanju horizontalnim inovacijama, tj. idejama koje vode proizvodnji novih vrsta proizvoda, a ta prva grana se temelji na Romeru (1990). Radovi u drugoj grani tehnološki napredak objašnjavaju vertikalnim inovacijama, tj. idejama koje vode unapređivanju postojećih proizvoda, a ova se grana temelji na Aghionu i Howittu (1992). Obe grane tehnološki napredak vide kao rezultat nastanka i razvoja novih ideja, koje nastaju svjesnim ulaganjem ekonomskih subjekata. Razlika između ove dvije grane je ta što Romer (1990) smatra da je tehnološki napredak posljedica horizontalnih inovacija, a Aghion i Howitt (1992) smatraju da je tehnološki napredak posljedica vertikalnih inovacija. Za objašnjenje ove razlike, Malešević i Ćorić (2013) koriste sektor prometa i tehnološki napredak ovog sektora. Prema Romerovom stajalištu povećanje efikasnosti u ovom sektoru bilo bi zbog proizvodnje

novih vrsta proizvoda kao što su novi automobili, vlakovi i sl., što je posljedica horizontalnih inovacija. Prema Aghionovom i Howittovom stajalištu, povećanje efikasnosti u ovom sektoru bilo bi zbog unapređenja postojećih proizvoda, npr. povećanje brzine vlakova, što je posljedica vertikalnih inovacija. Promatrajući današnje stanje u sektoru prometa, dolazi se do zaključka da je tehnološki napredak posljedica i horizontalnih i vertikalnih inovacija.

Mervar (1999) smatra da u modelima endogenog rasta vezanih za istraživanje i razvoj stopa rasta ovisi o nekoliko faktora:

- o ulaganju u istraživanje i razvoj
- o stupnju monopolske moći, tj. stupnju privatnog korištenja nove tehnologije
- o vremenskom horizontu investitora

Malešević i Ćorić (2013) zaključuju da je u modelu endogenog rasta koji je vezan za istraživanje ravnotežna stopa rasta BDP-a po radniku određena ulaganjem u istraživanje i razvoj. Ovakav zaključak znači da bi nositelju ekonomske politike trebali poticati ulaganja u istraživanje i razvoj. Ravnotežna stopa rasta BDP-a po radniku također ovisi o produktivnosti istraživanja. Promatrano iz mikroekonomske perspektive, nositelji ekonomske politike mogu malo toga napraviti jer ne postoje mjere koje bi recimo utjecale na stvaranje boljih ideja. Promatrano iz makroekonomske perspektive, nositelji ekonomske politike ipak mogu donekle utjecati na produktivnost istraživanja putem različitih mjera kojima bi se utjecalo na kvalitetu obrazovanja u nekoj državi (s naglaskom na visoko obrazovanje) te na poboljšanje obrazovanja ljudi koji sudjeluju u samom procesu istraživanja.

2.4.3. SUVREMENI TEORIJSKI MODELI KOJI POVEZUJU ULAGANJE U ISTRAŽIVANJE I RAZVOJ SA GOSPODARSKIM RASTOM

Tomljanović (2017b) navodi da krajem 20.stoljeća nastaju novi teorijski modeli (u odnosu na neoklasični model rasta i na endogene modele rasta) koji povezuju ulaganje u istraživanje i razvoj sa ekonomskim rastom. Ti novi teorijski modeli se dosta oslanjaju na prijašnje modele, posebno na teoriju endogenog rasta. Zajednička karakteristika tih novih teorijskih modela je temeljenje ekonomskog rasta na koncentraciji poduzeća koje stalno ulažu i istraživanje i razvoj te ostvaruju i održavaju suradnju sa vlašću, obrazovnim institucijama i sl. „Neki od novih koncepata poznati su pod nazivima novi industrijski prostor, industrijski klasteri, inovativni milje, samoučeća regija ili regionalni inovativni sustav“ (Lawson, 1997 navedeno u Tomljanović, 2017b).

Tomljanović (2017b) objašnjava da novi teorijski modeli koji povezuju istraživanje i razvoj sa gospodarskim rastom ističu dva izvora pozitivnih eksternalija, lokalizacija i urbanizacija. Lokalizacija je izvor pozitivnih eksternalija jer su poduzeća iz istog sektora blizu jedni drugima pa se na tom području ljudi specijaliziraju za taj sektor pa je zbog toga malo vjerojatno da poduzeća teško naći radna snage za taj sektor, na tom području. Lokalizacija je pogodna i za radnike koji će imati veći broj poslodavaca, pa će imati veći izbor. Lokalizacija također donosi i veću suradnju između poduzeća i zaposlenika istog sektora na tom području, što bi moglo pozitivno utjecati na poduzeća i na zaposlenike. Urbanizacija je izvor pozitivnih eksternalija jer su poduzeća iz različitih sektora blizu jedni drugima pa je veća šansa za suradnju između tih poduzeća jer međusobno nisu konkurenti. Također, u blizini su i ostale uslužne djelatnosti kao što su npr. konzultantske kuće i sl. pa bi to sve skupa trebalo pozitivno utjecati na poduzeća, zaposlenike i cjelokupan život na tom području. Piore i Sabel (1984), kako je navedeno u radu Tomljanovića (2017b), zaključuju kako je geografska blizina poduzeća puno bolja za razvoj inovacija nego raspršenost poduzeća na nekom prostoru. Ovaj zaključak su donijeli na temelju svog istraživanja o čimbenicima inovativnosti klastera u Sjevernoj Italiji. Armstrong i Taylor (2000), kako je navedeno u radu Tomljanovića (2017b), smatraju da je mali broj regija koje su pravi primjeri lokalizacije i urbanizacije. Kao prave primjere naveli su Silicon Valley i Boston (SAD), Cambridge (Velika Britanija), Darmstadt i München (Njemačka) i sl. Ove regije su primjer inovativnog miljea. Inovativni milje je vrsta klastera kojoj je glavna karakteristika prelijevanje znanja i vještina iz jednog poduzeća ili institucije na ostala poduzeća ili institucije u toj regiji, pa bi na taj način neka regija mogla ostvariti konkurentske prednosti.

U svom radu Tomljanović (2017b) zaključuje da navedeni novi teorijski modeli koji povezuju ulaganje u istraživanje i razvoj sa gospodarskim rastom nemaju značajnu teorijsku važnost kao što imaju npr. teorije endogenog rasta zbog toga što je ove modele teško matematički modelirati te zbog toga što se ovi modeli rijetko bave problemima. Bez obzira na ove nedostatke, ovi modeli doprinose boljem razumijevanju gospodarskog rasta.

3. EMPIRIJSKI DIO RADA

3.1. PRETHODNA EMPRIJSKA ISTRAŽIVANJA

U svom radu Skoko i Kandžija (2013) analizirali su povezanost između stope rasta BDP-a i komponenti istraživanja i razvoja u EU koristeći Pearsonov koeficijent korelacije (R) koji

pokazuje smjer i jačinu povezanosti između varijabli. Analizirana je 271 regija druge razine (NUTS II) i pet podskupina regija formiranih na temelju visine BDP-a u odnosu na prosjek EU za 2007., 2008. i 2009. godinu. Regije su podijeljene po skupinama razvijenosti na temelju BDP-a po PPP-u (paritetu kupovne moći) u promatranoj godini. Nakon provedene analize, dolazi se do zaključka kako nema značajne povezanosti između stope rasta BDP-a u regijama EU i ukupnih ulaganja u istraživanje i razvoj. U niti jednoj promatranoj godini ne postoji značajna pozitivna povezanost između ove dvije varijable.

Sokolov-Mladenović et.al (2016) statistički analiziraju utjecaj ulaganja u istraživanje i razvoj na ekonomski rast u EU (EU-28) za razdoblje od 2002. do 2012. godine koristeći 4 kontrolne varijable: stopa fertiliteta (plodnosti), financijska kriza, državni izdaci za finalnu potrošnju i investiranje u dugotrajnu imovinu. Nakon statističke analize, autori zaključuju da postoji pozitivan utjecaj ulaganja u istraživanje i razvoj na ekonomski rast.

Frederiksson i Andersson (2018) statistički analiziraju utjecaj istraživanja i razvoja na rast BDP-a na uzorku od 60 država za razdoblje od 1996.-2015. g. Zavisna varijabla u modelu je rast BDP-a, a nezavisne su: rast radne snage (%), rast kapitala (%), rast izdvajanja za istraživanje i razvoj (% BDP-a), korupcija (indeks percepcije korupcije) i trgovinska otvorenost (% BDP-a). Rezultati statističke analize ukazuju na to da rast izdvajanja za istraživanje i razvoj pozitivno utječe na rast BDP-a.

3.2. STATISTIČKA ANALIZA UTJECAJA ULAGANJA ISTRAŽIVANJA I RAZVOJA NA STOPU RASTA BDP-A

3.2.1. UVOD

U empirijskom dijelu ovog rada upotrebom se AB GMM(Arellano-Bond Generalized Method of Moments) procjenitelja u 2 koraka testira se utjecaj istraživanja i razvoja na rast BDP-a. Opravdanost upotrebe panel procjenitelja proizlazi iz obilježja varijabli koje se definiraju za zemlje Europske unije (EU-28) u razdoblju od 2007. do 2018. godine. U ovom dijelu rada testira se utjecaj ulaganja u istraživanje i razvoj na rast BDP-a uz kontrolne varijable: investicije (FDI), državna potrošnja, kretanje populacije, inflacija i dužnička kriza. Za potrebe testiranja utjecaja kretanja ulaganja u istraživanje i razvoj na kretanje stope rasta BDP-a uz odabrane kontrolne varijable koristi se dinamički panel model koji sadržava

zavisnu varijablu s vremenskim pomakom za jedan. U ovom dijelu koristit će se metode grafičkog i tabelarnog prikazivanja podataka.

3.2.2. ODABIR KONTROLNIH VARIJABLI U MODELU I NJIHOV OČEKIVANI UTJECAJ NA RAST BDP-A

U svom radu Kersan-Škabić i Zubin (2009) analiziraju utjecaj **izravnih inozemnih ulaganja (FDI)** na rast BDP-a. Marić i Matić (2018) navodi da su izravna inozemna ulaganja (FDI) sve vrste ulaganja stranih pravnih i fizičkih osoba u gospodarstvo neke zemlje. Jovančević (2007), kako je navedeno u radu Kersan-Škabić i Zubin (2009), preko svoje analize zaključuje da izravna ekonomska ulaganja (FDI) pozitivno utječu na stopu rasta BDP-a.

U svom radu Nelson i Singh (1994) koriste **inflaciju i javnu potrošnju** kao nezavisne varijable i analiziraju utjecaj tih varijabli na stopu rasta BDP-a. Analizirajući uzorak od 70 zemalja u razvoju za razdoblje od 1970.-1979.g., autori dolaze do zaključka da inflacija i javna potrošnja negativno utječu na stopu rasta BDP-a. Ghosh i Phillips (1998), kako je navedeno u radu Mervar (1999), utvrdili su signifikantnu negativnu vezu između inflacije i rasta BDP-a korištenjem panel regresije i nelinearne tehnike „binary recursive trees“ na uzorku od 145 zemalja za razdoblje od 1960-1996. g. Procjena parametara vršila se putem OLS metode. Wu i sur. (2010), kako je navedeno u radu Jurasović (2018), primjenom panel analize na uzorku od 182 zemlje zaključuju da državna potrošnja pozitivno utječe na ekonomski rast.

U svom radu Breznički (2013) navodi da je **dužnička kriza** stanje u kojem neka država ne može otplatiti svoje vanjske dugove, a posljedice dužničke krize su:

- porast kamatnih stopa na nove zajmove
- smanjena mogućnost novih zajmova
- pad vrijednosti dionica
- pad vrijednosti državnih obveznica
- pad povjerenja i sigurnosti u tu zemlju

Nikolić (1999) smatra da država ne može bankrotirati jer ona može:

- refinancirati dospelje dugove
- putem poreza skupiti novac za otplatu duga
- koristiti primarnu emisiju za vraćanje dugova

Furceri i Zdzenicka (2011) statistički analiziraju utjecaj dužničke krize na stopu rasta BDP-a putem panel podataka na uzorku od 154 zemlje za razdoblje od 1970.-2008.g. koristeći OLS i GMM metode procjene parametara. Rezultati analize pokazuju da dužnička kriza negativno utječe na stopu rasta BDP-a.

Malešević i Ćorić (2013) grafički analiziraju utjecaj porasta stanovništva (**populacije**) na stopu rasta BDP-a (po radniku) putem jednostavnog Solowljevog modela, a grafička analiza ukazuje na to da je utjecaj rasta populacije na stopu rasta BDP-a (po radniku) negativan.

Na temelju endogenog modela rasta koji sugerira da je ravnotežna stopa rasta BDP-a po radniku određena ulaganjem u istraživanje i razvoj, Malešević i Ćorić (2013) smatraju da bi se nositelji ekonomske politike trebali posvetiti mjerama i politikama koje potiču **ulaganja u istraživanje i razvoj**, pa se na temelju ovoga može zaključiti da ulaganje u istraživanje i razvoj pozitivno utječe na rast BDP-a.

Tablica 1: Varijable modela

Varijabla	Skraćeni naziv	Indikator	Izvor	Očekivan utjecaj na BDP
BDP	bdpr	Stopa rasta BDP-a (godišnja, %)	Worldbank	n/a, zavisna varijabla
BDP s vremenskim odmakom	l.bdpr	Stopa rasta BDP-a (godišnja, %)	Worldbank	
R&D izdaci	R&D	Izdavanja za istraživanje i razvoj (%BDP-a)	Worldbank	+
Investicije	FDI	FDI (%BDP-a)	Worldbank	+
Državna potrošnja	država	Državna potrošnja (%BDP-a)	Worldbank	+
Populacija	pop	Godišnji rast populacije (%)	Worldbank	-
Inflacija	cijene	Promjena potrošačkih cijena (godišnja, %)	Worldbank	-
Dužnička kriza	du_kriza	Dummy 0=nema krize, 1= pristuna kriza	Izrada autora	-

Izvor: Izrada autora

3.2.3.SPECIFIKACIJA MODELA

Procjenjuje se model:

$$bdpr_{it} = \alpha + \beta_1 l.bdpr_{it} + \beta_2 rd_{it} + \beta_3 fdi_{it} - \beta_4 pop_{it} + \beta_5 drzava_{it} - \beta_6 cijene_{it} - \beta_7 du_kriza + \varepsilon_{it};$$

$i = 1, \dots, 28; t = 2007. - 2018.$

gdje je:

bdpr- stopa rasta BDP-a

l.bdpr ostvarena stopa rasta BDP-a u godini koja prethodi promatranoj godini

α – konstantni član

t – broj razdoblja;

i – broj zemalja koje analiziramo

$\beta_1, \beta_2, \beta_3, \beta_4, \beta_5, \beta_6, \beta_7$ - parametri koje treba procijeniti

ε -slučajna varijabla

3.2.4. GRAFIČKA ANALIZA VARIJABLI


Iz grafičkog prikaza se može utvrditi da je u 2009. godini kod svih promatranih zemalja ostvaren pad stope rasta BDP-a sa različitim intenzitetom ovisno o zemlji.



Graf 6: Kretanje stope rasta BDP-a u EU (EU-28) u razdoblju od 2007. do 2018. godine

Izvor: Izrada autora


Iz grafičkog prikaza se može utvrditi da su u prosjeku sve promatranje zemlje ostvarile negativne stope rasta BDP-a u 2009. godini, nakon čega je uslijedio rast gospodarstva EU-28 sa tendencijom ubrzavanja rasta do kraja promatranog razdoblja.



Graf 7: Kretanje prosječne stope rasta BDP-a u EU (EU-28) u razdoblju od 2007. do 2018. godine

Izvor: Izrada autora


Prosječan udio ulaganja u istraživanje i razvoj u BDP-u u EU-28 je u cijelom promatranom razdoblju imao tendenciju rasta sve do 2014. godine kada je vidljiv pad prosječnog udjela ulaganja u istraživanje i razvoj u BDP-u.



Graf 8: Kretanje prosječnog udjela ulaganja u istraživanje i razvoj u BDP-u u EU-28 za razdoblje od 2007. do 2016. godine

Izvor: Izrada autora


Prosječan udio FDI ulaganja u BDP-u u EU-28 bilježio je oscilacije u promatranom razdoblju, a vidljiva je i tendencija pada udjela prosječnog FDI-a u BDP-u.



Graf 9: Kretanje prosječnog udjela FDI-a u BDP-u u EU-28 za razdoblje od 2007. do 2018. godine

Izvor: Izrada autora


Prosječna stopa rasta populacije u EU-28 za razdoblje od 2007. do 2018. godine, bilježila je pad do 2011. godine, nakon čega je uslijedilo razdoblje rasta koje je trajalo do 2015. godine, a nakon toga su bilježene manje korekcije.



Graf 10: Kretanje prosječne stope rasta populacije u EU-28 za razdoblje od 2007. do 2018. godine

Izvor: Izrada autora


Prosječni udio državne potrošnje u BDP-u u EU-28 za razdoblje od 2007. do 2018. godine bilo je najveće u kriznoj 2009. i 2010 godini, nakon čega je uslijedilo razdoblje tendencije pada sve do kraja promatranog razdoblja.



Graf 11: Kretanje prosječnog udjela državne potrošnje u BDP-u u EU-28 za razdoblje od 2007. do 2018. godine

Izvor: Izrada autora


Prosječna stopa inflacije u EU-28 bilježila je oscilacije u promatranom razdoblju sa tendencijom pada gdje je u 2015. godini ostvarena deflacija, nakon čega je uslijedilo razdoblje rasta.



Graf 12: Kretanje prosječne stope inflacije u EU-28 za razdoblje od 2007. do 2018. godine

Izvor: Izrada autora

Dužnička kriza je prvenstveno pogodila 5 EU zemalja: Portugal, Italiju, Irsku, Grčku i Španjolsku (PIIGS), a kasnije se nadovezala i na svjetsku gospodarsku krizu. U Europskoj Uniji je bila prisutna od 2009. do 2014. godine.



Graf 13: Prikaz pojave dužničke krize u EU-28 (promatrano razdoblje od 2007. do 2018. godine)

3.2.5. REZULTATI STATISTIČKE ANALIZE

3.2.5.1. DESKRIPTIVNA STATISTIKA

Tablica 2: Deskriptivna statistika

VARIJABLA	ARIT.SREDINA	STAND.DEVIJACIJA	MIN	MAX	BROJ OPSERVACIJA
bdpr	1.670982	3.744713	-14.81	25.12	336
rd	1.534786	0.8778729	0.38	3.75	280
fdi	10.53827	33.52053	-54.72	423.83	336
pop	0.2397321	0.8282001	-2.26	3.26	336
država	38.92377	7.657857	17.07	92.02	308
cijene	1.930387	2.141949	-4.48	15.4	336

Izvor: Izrada autora

Prosječna ostvarena stopa rasta BDP-a (bdpr) je 1,67%. Standardna devijacija je 3,77 postotnih poena, tj. prosječno odstupanje stope rasta BDP-a od prosjeka iznosi 3,77 p.p. Minimalna ostvarena stopa rasta BDP-a -14,81%, a maksimalna 25,12%.

Prosječno izdvajanje za istraživanje i razvoj (rd) iznosi 1,53% BDP-a. Standardna devijacija je 0,88 p.p., tj. prosječno odstupanje izdvajanja za istraživanje i razvoj(kao % BDP-a) od prosjeka iznosi 0,88 p.p. Minimalno izdvajanje za istraživanje i razvoj iznosi 0,38 % BDP-a, a maksimalno 3,75 % BDP-a.

Prosječni udio FDI-a u BDP-u iznosi 10,54 %. Standardna devijacija je 33,52 p.p., tj. prosječno odstupanje udjela FDI-a u BDP-u od prosjeka iznosi 33,52 p.p. Minimalni udio FDI-a u BDP-u iznosi -54,72 %, a maksimalni 423,83 %.

Prosječni godišnji rast populacije (pop) iznosi 0,24 %. Standardna devijacija iznosi 0,83 p.p., što znači da prosječno odstupanje godišnjeg rasta populacije od prosjeka iznosi 0,83 p.p. Minimalni godišnji rast populacije iznosi -2.26 %, a maksimalni 3,26 %.

Prosječna državna potrošnja (država) iznosi 38, 92 % BDP-a. Standardna devijacija iznosi 7,66 p.p., što znači da prosječno odstupanje državne potrošnje (kao % BDP-a) od prosjeka iznosi 7,66 p.p. Minimalna državna potrošnja iznosi 17,07 % BDP-a, a maksimalna 92,02 % BDP-a.

Prosječna promjena potrošačkih cijena (cijene) iznosi 1,93 %. Standardna devijacija iznosi 2,14 p.p., što znači da prosječno odstupanje promjene potrošačkih cijena od prosjeka iznosi 2,14 p.p. Minimalna promjena potrošačkih cijena iznosi -4,48 %, a maksimalna 15,4%.

3.2.5.2. PROCJENA VARIJABLI DINAMIČKOG PROCJENITELJA

U radu se koristi BB (Blundell-Bond) model koji uklanja nedostatke AB (Arellano-Bond) procjenitelja te omogućuje procjenu utjecaja odabranih varijabli bez obzira na postojanje ovisnosti o vremenu. BB model se u praksi pokazao efikasnijim od AB modela i ima bolja svojstva kod istraživanja gdje je broj razdoblja malen u odnosu na broj jedinica promatranja, što je slučaj i u ovom radu gdje je broj jedinica promatranja 28, a broj razdoblja 11.

3.2.5.3. TESTIRANJE MULTIKOLINEARNOSTI

Da bi procijenjeni model bio dobar, nužan, ali ne i dovoljan uvjet je nepostojanje problema multikolinearnosti među nezavisnim varijablama u modelu. Postojanje potencijalnog problema multikolinearnosti testira se korelacijom.

Tablica 3: Testiranje multikolinearnosti

	rd	fdi	pop	drzava	cijene	du_kriza
rd	1.0000					
fdi	-0.1440*	1.0000				
pop	0.2916*	0.2010*	1.0000			
drzava	-0.0616	0.2969*	-0.0102	1.0000		
cijene	-0.1761*	0.0146	-0.1652*	-0.0925	1.0000	
du_kriza	-0.1072	-0.0469	-0.0525	0.0866	-0.0694	1.0000

Izvor: Izrada autora

Iz tablice se može utvrditi postojanje tek slabih povezanosti među odabranim nezavisnim varijablama, zbog čega se može utvrditi da je potencijalni problem multikolinearnosti otklonjen.

3.2.5.4. DINAMIČKI PANEL PROCJENITELJ I PROCIJENJENI MODEL

Tablica 4: Dinamički panel procjenitelj

U empirijskom dijelu rada koristi se dinamički panel model. Glaurdić Mekinić (2016) navodi da je većina ekonomskih pojava dinamičke prirode, tj. da sadašnja vrijednost neke varijable ovisi o prethodnim vrijednostima te varijable. Za procjenu dinamičkog panel modela koristit će se AB GMM (Arellano-Bond Generalized Method of Moments) procjenitelj u 2 koraka. U svom radu Mačkić (2014) navodi prednosti AB GMM procjenitelja u 2 koraka. Prednosti se vide u tome što procjenitelj u jednom koraku pretpostavlja nezavisnost i identično distribuirane greške relacije, pa je zbog toga ovaj procjenitelj dobar odabir.

```
System dynamic panel-data estimation
Group variable: drzava_id
Time variable: godina

Number of obs      =      224
Number of groups   =       28

Obs per group:    min =      8
                  avg =      8
                  max =      8

Number of instruments =      23      wald chi2(7)      =    1974.98
                                      Prob > chi2      =      0.0000
```

Two-step results

bdpr	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
bdpr L1.	.1402449	.0374638	3.74	0.000	.0668172	.2136727
rd	1.19996	.571338	2.10	0.036	.080158	2.319762
fdi	.0226097	.0063214	3.58	0.000	.0102199	.0349994
pop	-1.351126	.3223679	-4.19	0.000	-1.982955	-.7192963
drzava	-.4230649	.0605111	-6.99	0.000	-.5416646	-.3044653
cijene	.3420761	.0200345	17.07	0.000	.3028092	.381343
du_kriza	-4.655224	.7511186	-6.20	0.000	-6.127389	-3.183058
_cons	15.95961	2.458245	6.49	0.000	11.14154	20.77768

Warning: gmm two-step standard errors are biased; robust standard errors are recommended.

Instruments for differenced equation

GMM-type: L(2/2).bdpr

Standard: D.rd D.fdi D.pop D.drzava D.cijene D.du_kriza

Instruments for level equation

GMM-type: LD.bdpr

Standard: _cons

Izvor: Izrada autora

Iz tablice se može utvrditi da su pri graničnoj signifikantnosti od 5% sve promatrane varijable statistički značajne.

Procijenjeni model:

$$bdpr_{it} = 15,96 + 0,14 * l.bdpr_{it} + 1,20 * rd_{it} + 0,02 * fdi_{it} - 1,35 * pop_{it} - 0,42 * drzava_{it} + 0,34 * cijene_{it} - 4,65 * du_kriza_{it} + \varepsilon_{it};$$

$$i = 1, \dots, 28; t = 2007. - 2018.$$

Vrijednost konstantnog člana 15,96 znači da je očekivana stopa rasta BDP-a 15,95% ukoliko bi ostale varijable u modelu poprimile vrijednost nula. Riječ je o statistički značajnom parametru.

Vrijednost parametra 0,14 uz varijablu stopa rasta BDP-a s vremenskim pomakom znači da se svakim porastom ostvarene stope rasta BDP-a u prethodnom razdoblju za jedan postotni bod očekuje veća stopa rasta BDP-a u tekućem razdoblju u prosjeku za 0,14 postotnih bodova.

Vrijednost parametra 1,20 uz varijablu ulaganja u istraživanje i razvoj znači da se svakim porastom udjela istraživanja i razvoja u BDP-u za jedan postotni bod očekuje veća stopa rasta BDP-a u tekućem razdoblju u prosjeku za 1,20 postotnih bodova. U uvodnom dijelu rada navedene su dvije hipoteze :

H0-nema značajnog utjecaja ulaganja u istraživanje i razvoj na rast BDP-a

H1-postoji značajan utjecaj ulaganja u istraživanje i razvoj na rast BDP-a

Rezultati statističke analize pokazuju da je varijabla ulaganje i istraživanje i razvoj statistički značajna pri razini signifikantnosti od 5% (p vrijednost $3,6\% < 5\%$), pa se prihvaća H1 hipoteza, tj. postoji značajan utjecaj ulaganja u istraživanje i razvoj na rast BDP-a.

Vrijednost parametra 0,02 uz varijablu investicija (FDI) znači da se svakim porastom udjela investicija(FDI) u BDP-u za jedan postotni bod očekuje veća stopa rasta BDP-a u tekućem razdoblju u prosjeku za 0,02 postotnih bodova.

Vrijednost parametra -1,35 uz varijablu stopa rasta populacije znači da se svakim porastom populacije za jedan postotni bod očekuje manja stopa rasta BDP-a u tekućem razdoblju u prosjeku za 1,35 postotnih bodova.

Vrijednost parametra -0,42 uz varijablu državna potrošnja znači da se svakim porastom udjela državne potrošnje u BDP-u za jedan postotni bod očekuje manja stopa rasta BDP-a u tekućem razdoblju u prosjeku za 0,42 postotnih bodova.

Vrijednost parametra 0,34 uz varijablu kretanja cijena znači da se svakim porastom razine cijena za jedan postotni bod očekuje veća stopa rasta BDP-a u tekućem razdoblju u prosjeku za 0,34 postotnih bodova.

Vrijednost parametra -4,66 uz varijablu dužnička kriza znači da se u vremenu dužničke krize očekuje manja stopa rasta BDP-a u tekućem razdoblju u prosjeku za 4,66 postotnih bodova.

3.2.5.5. TESTIRANJE PROBLEMA ENDOGENOSTI I AUTOKORELACIJE

Sargan test of overidentifying restrictions

H0: overidentifying restrictions are valid

chi2(15) = 21.6603
Prob > chi2 = 0.1170

Slika 3: Sarganov test

Izvor: Izrada autora

Sarganovim testom se testira valjanost instrumenata za procjenu modela. Na temelju empirijske Hi kvadrat vrijednosti 21,66 donosi se zaključak da u procjenitelju nije prisutan problem endogenosti, odnosno da su instrumenti valjani te je model primjereno koristiti za daljnje procjene. Zaključak je donesen na temelju empirijske razine signifikantnosti od 11,70%.

Tablica 5: Testiranje problema autokorelacije

Arellano-Bond test for zero autocorrelation in first-differenced errors

Order	z	Prob > z
1	-1.1757	0.2397
2	-1.218	0.2232

H0: no autocorrelation

Izvor: Izrada autora

Iz tablice se može utvrditi da među prvim difrencijama reziduala nema problema autokorelacije (empirijska p vrijednost 23,97% > 5,00%), kao ni među difrenciranim rezidualima drugog reda (empirijska p vrijednost 22,32% > 5%) te se može zaključiti da u modelu ne postoji problem autokorelacije.

3.3. RASPRAVA REZULTATA

Tablica 6: Usporedba očekivanog i ostvarenog utjecaja varijabli na BDP


Varijabla	Skraćeni naziv	Očekivan utjecaj na BDP	Ostvaren utjecaj
BDP s vremenskim odmakom	l.bdpr	+	+
R&D izdaci	rd	+	+
Investicije	fdi	+	+
Državna potrošnja	drzava	+	-
Populacija	pop	-	-
Inflacija	cijene	-	+
Dužnička kriza	du_kriza	-	-

Izvor: Izrada autora

Većina testiranih varijabli ima jednak očekivani i ostvareni utjecaj, samo državna potrošnja i inflacija imaju različit očekivani i ostvareni utjecaj. Ostvareni utjecaj državne potrošnje na BDP je negativan i razlikuje se od očekivanog utjecaja (pozitivnog). U svom radu Jurasović (2018) statistički analizira utjecaj ukupnih javnih rashoda (državna potrošnja) na ekonomski rast RH i nakon rezultata analize, dolazi do zaključka da je taj utjecaj statistički značajan i negativan, tako da taj utjecaj može biti pozitivan i negativan. Ostvareni utjecaj inflacije na BDP je pozitivan i razlikuje se od očekivanog (negativnog). Frey i Stutzer (2002), kako je navedeno u radu Malešević Perović (2008), navode da većina ekonomista misli da vrlo visoka inflacija negativno utječe na gospodarstvo, a da niska i stabilna inflacija (od 1% do 5% godišnje) čak može biti i korisna, tako da i taj utjecaj može biti negativan i pozitivan. Ostvareni utjecaj ulaganja u istraživanje i razvoj na rast BDP-a je u skladu sa prethodnim rezultatima empirijskih istraživanja: Frederiksson i Andersson (2018) i Sokolov-Mladenović et.al (2016). Ostvareni utjecaj dužničke krize na stopu rasta BDP-a također je u skladu s prethodnim rezultatom emirijskom istraživanja; Furceri i Zdzienicka (2011). Ostvareni utjecaj investicija na stopu rasta BDP-a u skladu je sa prethodnom analizom ; Jovančević (2007), kako je navedeno u radu Kersan-Škabić i Zubin (2009), a ostvareni utjecaj populacije na stopu rasta BDP-a u skladu je sa rezultatima grafičke analize autora Malešević i Ćorić (2013).

U ovom modelu ne postoje problemi autokorelacije i multikolinearnosti., a u procjenitelju ne postoji problem endogenosti, pa je model primjereno koristiti za daljnje procjene.

Iz grafičkog prikaza se može utvrditi da procijenjeni model pobliže definira kretanja ostvarenog BDP-a u promatranom razdoblju, zbog čega je primjeren za korištenje za procjene u budućnosti.



Graf 14: Usporedba ostvarenih i modelskih stopa rasta BDP-a

Izvor: Izrada autora

4. ZAKLJUČAK

Istraživanje i razvoj zauzima sve bitniju ulogu u ekonomiji. Ulaganjem u istraživanje i razvoj države mogu ostvariti konkurentske prednosti. Država ima bitnu ulogu u poticanju istraživanja i razvoja jer ona može olakšati ulaganja putem poreznih politika i mjera, suradnje znanosti, države i poduzeća i sl. Također, država može utjecati i na obrazovanje i tako omogućiti „obučene“ zaposlenike u sektoru istraživanja i razvoja koji bi trebali pozitivno utjecati na taj sektor. Inovacije su jako važan dio istraživanja i razvoja jer se putem njih dolazi do novih izuma, proizvoda, procesa i sl.

Europska Unija potiče ulaganja zemalja članica. Privatni sektor je jako bitan za istraživanje i razvoj u EU-28 jer je taj sektor glavni izvor financiranja ulaganja u istraživanje i razvoj u EU-28. SAD i Japan više ulažu u istraživanje i razvoj od Europske Unije (ulaganje u istraživanje i

razvoj kao % BDP-a), pa je to još jedan motiv Europske Unije za poticanje zemalja članica na ulaganje u istraživanje i razvoj jer je Japan tehnološka velesila, a SAD je uvijek bio ekonomski „rival“ Europi.

Postoje brojni teorijski modeli koji objašnjavaju i brojna empirijska istraživanja koja ispituju utjecaj ulaganja u istraživanje i razvoj na ekonomski rast (rast BDP-a). Takva empirijska istraživanja razlikuju se po odabranim varijablama, vrsti statističke analize i po rezultatima. Nakon odabira varijabli, definiranja modela i statističke analize u empirijskom dijelu ovoga rada, zaključak je da postoji pozitivan utjecaj ulaganja u istraživanje i razvoj na rast BDP-a.

Postignut je glavni cilj ovog istraživanja, tj. analizirana je veza između ulaganja u istraživanje i razvoj i rasta BDP-a na temelju pregleda teorijske i empirijske literature i na temelju statističke analize. Postignuti su i pomoćni ciljevi ovog istraživanja na temelju grafičke analize, tj. analizirano je koliko se ulaže u istraživanje i razvoj u državama EU, koji su izvori sredstava za istraživanje i razvoju EU i koji je udio osoba koje rade u sektoru istraživanja i razvoja u ukupnoj radnoj snazi zemalja članica EU.

Utjecaj ulaganja u istraživanje i razvoj na ekonomski rast (rast BDP-a) je relativno moderna tema o kojoj se nije toliko pisalo i otvara prostor novim empirijskim istraživanjima i zaključcima.

LITERATURA

1. Aghion, P. i Howitt, P. (1992), A model of growth through creative destruction. *Econometrica*, Vol. 60, No. 2, str. 323-351.
2. Aghion, P., Bloom, N., Blundell, R., Griffith, R. i Howitt, P. (2005), Competition and Innovation: An Inverted-U Relationship. *The Quarterly Journal of Economics*, 120 (2), str. 701-728.
3. Armstrong, M. i Taylor, J. (2000), Regional economics and policy. Treće izdanje. Oxford : Blackwell.
4. Bassanini, A., Scarpetta, S. i Visco, I. (2000), Knowledge, Technology And Economic Growth: Recent Evidence From OECD Countries. Economics Department. Working Papers No. 259. Dostupno na: <http://data.vatt.fi/knogg/Docs/Visvotech-growth-OECDwp.pdf> [pristupljeno 11.06.2018.].
5. Bečić, E. i Dabić, M. (2008), Analiza ulaganja poslovnog sektora RH. *Revija za sociologiju*, Vol 39 (1-2). str. 69-84.
6. Ben-David, D. i Loewy, M.B. (1998), Free trade, growth, and convergence. *Journal of Economic Growth*, 3, str. 143-170.
7. Bejaković, P. (2003), Financiranje istraživanja i razvoja. *Financijska teorija i praksa*, 27 (2), str. 181-212 .
8. Bilas, V., Franc, S. (2018), Inovacije i razvoj. Zagreb: Notitia d.o.o.
9. Breznički, Z. (2013), Utjecaj financijskih kriza na nacionalno gospodarstvo. Završni rad. Koprivnica: Sveučilište Sjever, Sveučilišni centar Koprivnica.
10. Cameron, G. (1998.): Innovation and growth: a survey of the empirical evidence. Oxford: Nuffield College, Oxford University.
11. Društveno odgovorno poslovanje u Hrvatakoj (2012): Istraživanje i razvoj, raspoloživo na: <http://www.dop.hr/?p=676> , [pristupljeno 17.04.2019.].
12. DZS (2005) : Statistički ljetopis 2005., raspoloživo na: https://www.dzs.hr/Hrv_Eng/ljetopis/2005/00-sadrzaj.pdf , [pristupljeno 20.09.2019.].
13. DZS (2018): Istraživanje i razvoj u 2017., raspoloživo na: https://www.dzs.hr/Hrv_Eng/publication/2018/08-02-01_01_2018.htm, [pristupljeno 20.09.2019.].
14. Europska unija (2016): Istraživanje i inovacije, raspoloživo na: https://europa.eu/european-union/topics/research-innovation_hr, [pristupljeno 22.05.2018.].

15. Eurostat (2018): R&D expenditure, raspoloživo na: https://ec.europa.eu/eurostat/statistics-explained/index.php/R_%26_D_expenditure, [pristupljeno 17.04.2019.].
16. Etzkowitz, H. (2002), Incubation of incubators: innovation as a triple helix of university-industry-government networks. *Science and Public Policy*, vol. 29, issue 2, str. 115-128.
17. Fredriksson, T. i Andersson, F. (2018), *Economic Performance and R&D*. Završni rad. Jonkoping: Jonkoping University- International Business School
18. Frey, B., Stutzer, A. (2002), What can Economists Learn from Happiness Research? *Journal of Economic Literature*, 40 (2), str. 520-578.
19. Furceri, D., Zdzenicka, A. (2011), How costly are debt crises? Raspoloživo na: https://mpira.ub.uni-muenchen.de/30953/1/MPRA_paper_30953.pdf, [pristupljeno 22.08.2019.].
20. Galović, T. (2016), *Uvod u inovativnost poduzeća*. Rijeka: Sveučilište u Rijeci- Ekonomski fakultet
21. Ghosh, A., Phillips, S. (1998), *Inflation, Disinflation, and Growth*, IMF Working Papers, Washington, D.C.: International Monetary Fund.
22. Glaurdić Mekinić, A. (2016), *UTJECAJ MAKROEKONOMSKIH POKAZATELJA EMITIVNIH ZEMALJA NA BROJ NOĆENJA TURISTA U PRIMORSKIM ŽUPANIJAMA REPUBLIKE HRVATSKE: PANEL MODEL*. Diplomski rad. Split: Sveučilište u Splitu- Ekonomski fakultet.
23. Guellec, D., Van Pottelsberghe, B. (2003), The impact of public R&D expenditure on business R&D, *Economics of innovation and new technology*, 12 (3), str. 225-243.
24. Gulam, T. (2016), *Borba protiv inflacije*. Završni rad. Split: Sveučilište u Splitu- Ekonomski fakultet.
25. Hodžić, S. (2012), *Stimulacija poreznih olakšica za istraživanje i razvoj*. Skrivena javna potrošnja: sadašnjost i budućnost poreznih izdataka. Zagreb: Institut za javne financije, str. 151-160.
26. Hodžić, S. (2014), *Oporezivanje dobiti i porezni poticaji za istraživanje i razvoj*. Doktorska disertacija. Opatija: Fakultet za menadžment u turizmu i ugostiteljstvu, Opatija
27. Jovančević, R. (2007.), *The Impact of Foreign Investments Flows on Croatian Economy- A Comparative Analysis*,. *Ekonomski pregled*, 12 (58), str. 826-850.

28. Jovičić, J., Petković, S. (2016), Inovacije kao čimbenik konkurentnosti privrede s osvrtom na Bosnu i Hercegovinu. *Obrazovanje za poduzetništvo*, 6 (1), str. 99-109.
29. Jurasović, A.M. (2018), Utjecaj javnih rashoda na ekonomski rast-primjer Hrvatske. *Diplomski rad*. Split: Sveučilište u Splitu-Ekonomska fakultet.
30. Kersan-Škabić, I., Zubin, C. (2009), Utjecaj izravnih inozemnih ulaganja na rast BDP-a, na zaposlenost i na izvoz u Hrvatskoj. *Ekonomski pregled*, 60 (3-4), str.119-151.
31. Kojić, J., Jakšić, M.L., Marinković, S., Petković, J. (2011), Istraživanje i razvoj kao indikator performansi tehnološkog razvoja. *Operacioni menadžment u funkciji održivog ekonomskog rasta i razvoja Srbije 2011-2020*. Beograd: Fakultet organizacionih nauka, str. 59-66.
32. Kraljić, T. (2016), Horizontalna i vertikalna konzistentnost strateškog planiranja-odgovornost quadruple helix dionika u djelotvornom upravljanju razvojem u Republici Hrvatskoj. *Doktorska disertacija*. Osijek: Ekonomska fakultet
33. Lawson, C. (1997) , *Territorial Clustering and High Technology Innovation: From Industrial Districts to Innovative Milieux*. ESRC Centre for Business Research. Cambridge: University of Cambridge
34. Lažnjak, J., Švarc, J. (2001), *Upravljačke elite u inovativnom društvu*. Čengić, D., Rogić, I. (ur.). *Upravljačke elite i modernizacija*. Zagreb: Institut društvenih znanosti Ivo Pilar, str. 145-166
35. Lucas, R. E. (1988), On the mechanics of economic development, *Journal of Monetary Economics*, (22), str. 3-42.
36. Mačkić, V. (2014), Političko-proračunski ciklusi na uzorku hrvatskih gradova. *EFZG- serija članaka u nastajanju*, 14 (1).
37. Malešević Perović, L. (2008), Subjektivno ekonomsko zadovoljstvo u tranzicijskim zemljama: istraživanje relativne važnosti makroekonomskih varijabli. *Financijska teorija i praksa*, 32 (4), str. 523-542 .
38. Malešević Perović, L. i Ćorić, B. (2013), *Makroekonomija: teorija i politika*. Split: Sveučilište u Splitu-Ekonomska fakultet
39. Marić, K., Matić, J. (2018), Inozemna izravna ulaganja u Republiku Hrvatsku i usporedba s odabranim nerazvijenim zemljama. *Zbornik sveučilišta Libertas*. Zagreb: Libertas međunarodno sveučilište, str. 147-167.

40. Mervar, A. (1999), Pregled modela i metoda istraživanja gospodarskog rasta. Privredna kretanja i ekonomska politika, 9 (73), str. 20-61.
- 41..MZOŠ (2008), Akcijski plan za poticanje ulaganja u znanost i istraživanje, URL: [http://novebojeznanja.hr/UserDocsImages/Dokumenti%20i%20publikacije/Dokumenti%20i%20publikacije%20referirani%20u%20SOZT-u%20\(popis%201\)/146%20Akcijski%20plan%20za%20poticanje%20ulaganja%20u%20znanost%20i%20istra%C5%BEivanje.pdf](http://novebojeznanja.hr/UserDocsImages/Dokumenti%20i%20publikacije/Dokumenti%20i%20publikacije%20referirani%20u%20SOZT-u%20(popis%201)/146%20Akcijski%20plan%20za%20poticanje%20ulaganja%20u%20znanost%20i%20istra%C5%BEivanje.pdf), [pristupljeno 07.07..2019.].
42. Nelson, M., Singh, R.D. (1994), The Deficit-Growth Connection: Some Recent Evidence from Developing Countries. Economic development and cultural change, 43(1), str. 91-167.
43. Nikolić, N. (1999), Počela javnog financiranja. Split: Ekonomski fakultet
44. OECD (2002), Frascati Manual: proposed standards practice for surveys on research and experimental development. Paris: OECD.
45. OECD (2007), Innovation and growth: Rationale for an innovation strategy, dostupno na: <https://www.oecd.org/science/inno/39374789.pdf>, [pristupljeno 13.07..2019.].
46. OECD (2013), RAZVOJ PRIVATNOG SEKTORA-PRIRUČNIK ZA POLITIKE: Triple Helix partnerstva za inovacije u Bosni i Hercegovini, raspoloživo na: <https://www.oecd.org/south-east-europe/programme/Triple%20Helix%20Croatian.pdf>, [pristupljeno 08.07..2019.].
47. Pavlišić P. (2016), Inovacije i gospodarski rast: Koliko je jaka povezanost? Primjer njemačkog gospodarstva. Ekonomski pregled, 67 (5), str. 440-461.
48. Piore, M.J., Sabel, C.F. (1984), The Second Industrial Divide: Possibilities for Prosperity. New York: Basic Books.
49. Prester, J. (2010), Menadžment inovacija. Zagreb: SINERGIJA d.o.o.
50. Romer, P.M. (1990), Endogenous technological change. Journal of Political Economy, 98, str. 71-102.
51. Skoko, B., Kandžija, T. (2013), Utjecaj komponenti istraživanja i znanja na rast BDP-a europskih regija. Ekonomski vjesnik, 26 (1), str. 122-136.
52. Sokolov-Mladenović, S., Cvetanović, S., Mladenović, I. (2016), R&D expenditure and economic growth: EU28 evidence for the period 2002–2012. Economic research - Ekonomska istraživanja, 29 (1), str. 1005-1020.

53. Šimurina, N., Galić, B. (2017), Usporedna analiza poreznih poticaja za istraživanje i razvoj u Europskoj uniji. Zbornik Ekonomskog fakulteta u Zagrebu. Zagreb: Ekonomski fakultet, str. 105-126.
54. Tomljanović, M.(2017), Ulaganje u istraživanje i razvoj - čimbenik gospodarskog rasta Republike Hrvatske, Zbornik Ekonomskog fakulteta u Zagrebu. Zagreb: Ekonomski fakultet Zagreb, str.145-169
55. Tomljanović, M. (2017), Ulaganje u istraživanje i razvoj - čimbenik prilagodbe zemalja Zapadnoga Balkana gospodarstvu EU. Doktorski rad. Rijeka: SVEUČILIŠTE U RIJECI, EKONOMSKI FAKULTET RIJEKA.
56. Van Pottelsberghe, B., Nysten, S., Megally E. (2003), Evaluation of current scal incentives for business R&D in Belgium. Bruxelles: Universite Libre de Bruxelles.
57. Wu, S.Y., Tang, J.H., Lin, E.S. (2010): The impact of government expenditure on economic growth: How sensitive to the level of development? Journal of Policy Modeling, 32 (6), str. 804 – 817.
58. Zagler, M.(1998), Economic Growth and Protection of Emerging Markets in Eastern Europe. Journal of economic development, 23 (1), str. 21-36.

SAŽETAK

Istraživanje i razvoj su dva povezana, ali ipak različita pojma. Istraživanje se povezuje sa stvaranjem novog znanja, dok se razvoj povezuje s primijenjenim znanjem. Ulaganjem u istraživanje i razvoj, neka država može ostvariti komparativne prednosti i povećati zaposlenost, gospodarski rast i životni standard stanovništva. Europska Unija je prepoznala istraživanje i razvoj kao pokretač rasta i potiče zemlje članice na ulaganje u taj sektor. Utjecaj ulaganja u istraživanje i razvoj na rast BDP-a bio je tema mnogih modela i stručnih radova. Jedni od najznačajnijih su endogeni modeli rasta koji pokušavaju objasniti tehnološki napredak i dugoročni gospodarski rast kroz ulaganja u istraživanje i razvoj. Glavni cilj ovog rada bio je analizirati vezu između ulaganja u istraživanje i razvoj i rasta BDP-a na temelju pregleda teorijske i empirijske literature, istraživanja literature i regresijske analize. Nakon pregleda literature i izrade empirijskog dijela rada (statističke analize), donosi se zaključak da je utjecaj ulaganja u istraživanja i razvoj na rast BDP-a pozitivan.

Ključne riječi: istraživanje i razvoj, rast BDP-a, ulaganje u istraživanje i razvoj

SUMMARY

Research and development are two connected, but still different terms. Research is connected with creating new knowledge, while development is connected with applied knowledge. By investing in research and development, some country can accomplish comparative advantages and increase employment, economic growth and the standard of living of the population. European Union recognized research and development as a growth initiator and encourages member states to invest in that sector. The influence of research and development on GDP growth was the topic of many models and professional papers. Some of the most significant are endogenous growth models who are trying to explain technological advancement and long-term economic growth through R&D investment. The main objective of this paper was to analyze the link between R&D investment and GDP growth based on a review of theoretical and empirical literature, literature research and regression analysis. After reviewing the literature and compiling the empirical part of the paper (statistical analysis), it is concluded that the impact of R&D investment on GDP growth is positive.

Keywords: R&D, GDP growth, R&D investment